

Partie II

Suite du cours

"Analyse de Service"

§ - Estimateurs de la fct de risque R :

$$\text{on a : } R(t) = \frac{f(t)}{s(t)}$$

un estimateur de R : aux points t_i (réalisations de T_i)


$$\hat{R}_n(t_i) = \frac{m_i}{n_i} \quad \text{où } m_i = \text{nbre d'év}^{\text{ts}} \text{ observés à } t_i$$

$n_i = \text{nbre d'individus à risque à } t_i \text{ (avant } t_i \text{)}$

c'est le rapport entre le nombre d'év^{ts} ^{observés} et les cas possibles

Rappel : $R(t) := \lim_{\Delta \rightarrow 0} \frac{P(t < T < t + \Delta \mid T > t)}{\Delta}$

on fait une interpolation ^{linéaire} entre les points $(t_i, R(t_i))$
(ou polynômes, splines)



Rq : Il existe d'autres méthodes pour estimer la fonction de risque R.

§ 1. Estimation de S par la méthode actuarielle (Actuarial)

L'Actuariat est une science qui s'intéresse aux contrats d'assurance ~~pour~~ les risques.

Dans l'estimation de S par Kaplan-Meier, on a les instants t_i de la survenue de l'événement E ou censure, par contre pour assurer (compagnie de l'assurance) un individu contre des risques (voitures, habitation...) on ne dispose pas des points t_i à l'avance et on voudrait une estimation de S , ($S(t)$ = la "survie" à l'instant t) il existe une méthode appelée **Méthode Actuarielle** ou Actuarial.

§ 2. Méthode actuarielle :

On commence par partager l'intervalle $[0, +\infty[$ en sous-intervalles fixes : $]0, a_1]$, $]a_1, a_2]$, ..., $]a_{j-1}, a_j]$ pour le choix de sous-intervalles, il y a une étude préalable, et ^{ne sont} pas nécessairement égaux.

Comment estimer $S(t)$?

$$S(t) \quad t \in]a_{j-1}, a_j] \quad j = 1, \dots$$

$$S(t) = \mathbb{P}(T > t) = \mathbb{P}(T > t \mid T > a_{j-1}) \mathbb{P}(T > a_{j-1})$$

alors :

$$S(a_j) = \underbrace{\mathbb{P}(T > a_j \mid T > a_{j-1})}_{= q_j} \mathbb{P}(T > a_{j-1})$$

Ainsi : $S(a_j) = q_j \cdot q_{j-1} \cdots q_1$
 $= \prod_{i=1}^j q_i$

où $q_i = IP(T > a_i \mid T > a_{i-1})$
 $=$ proba de survivre ds $]a_{i-1}, a_i]$
 en a pas l'év^t ds cet intervalle

$q_j =$ proba de ne pas avoir E ds $]t_{j-1}, t_j]$

$p_i = 1 - q_i =$ proba d'avoir E ds $]a_{i-1}, a_i]$

Pour estimer q_i , on estime p_i .

on note : $e_i =$ le nombre d'individus à risque ds
 l'intervalle $]a_{i-1}, a_i]$.

$m_{i-1} =$ nombre d'individus qui ont subi l'événement ds
 $]a_{i-1}, a_i]$.

alors : $p_i \approx \frac{m_{i-1}}{e_i} =: \hat{p}_i$

La détermination des e_i et des m_{i-1} se fait par
 les compagnies d'assurance

* Détermination des e_i

1) Si dans l'intervalle $(a_{i-1}, a_i]$ il n'y a pas
 de censure, avec : $n_i =$ nombre d'individus à
 risque à l'instant a_i

on a : $n_i = n_{i-1} - m_{i-1}$

alors on choisit (un choix!) : $e_i = n_{i-1} = n_i + m_{i-1}$

2) s'il y a des données censurées ds $]a_{i-1}, a_i]$
 (la censure ici correspond à des individus
 qui se présentent (observés) au début puis
 disparaissent par la suite)

on choisit (choix!) $e_i = n_{i-1} - \frac{c_{i-1}}{2}$

où c_{i-1} = nbre d'individus censurés ds
 n_{i-1} avant a_{i-1} $]a_{i-1}, a_i]$.

Donc l'estimateur actuariel de S :

$$\hat{S}_a(a_j) = \prod_{i=1}^j \hat{q}_i \quad \text{ou} \quad \hat{q}_i = 1 - \frac{m_{i-1}}{e_i}$$

et $e_i = n_{i-1} - \frac{c_{i-1}}{2}$

$$\hat{S}_a(a_j) = \prod_{i=1}^j \left(1 - \frac{m_{i-1}}{n_{i-1} - \frac{c_{i-1}}{2}} \right) \quad j \geq 0$$

Reste $\hat{S}_a(t)$: on fait une interpolation linéaire
 des points $(a_j, \hat{S}_a(a_j))$ (car \hat{S}_a n'est cste
 ds l'intervalle $]a_{j-1}, a_j]$ car il y a des
 événements à l'intérieur.

• Estimateur de Nelson Aalen

La fonction de risque cumulée :

$$H(t) = \int_0^t R(s) ds \quad (\rightarrow F(t) = \int_0^t f(s) ds)$$

(somme des risques (risque cumulé))

Estimation de H :

On a : $H'(t) = R(t)$

or : $H(t_i + \Delta) - H(t_i) = \int_{t_i}^{t_i + \Delta} R(s) ds \approx \Delta \cdot R(t_i)$

ou encore :

$$H(t_i) - H(t_{i-1}) \approx R(t_i)$$

or $R(t_i) \approx \frac{m_i}{n_i}$

donc un estimateur de $H(t_i)$

$$\hat{H}_n(t_i) - \hat{H}_n(t_{i-1}) = \frac{m_i}{n_i}$$

d'où $\hat{H}_{NA}(t) = \sum_{t_j \leq t} \frac{m_j}{n_j}$ de Nelson Aalen

car : $\hat{H}_n(t_i) = \sum_{t_j \leq t_i} \frac{m_j}{n_j}$

$$\hat{H}_n(t_{i-1}) = \sum_{t_j \leq t_{i-1}} \frac{m_j}{n_j}$$

$H(t)$ c'est la somme des risques jusqu'à t_i

$H(t_{i-1})$ " " " " t_{i-1}

En faisant la différence il reste le risque à l'instant t_i

D'autres estimateurs de H :

De la formule $H(t) = -\log S(t)$,

~~on a~~ on a d'autres estimateurs de H :

$$\hat{H}_{KM}(t) = -\log \hat{S}_{KM}(t), \quad \hat{H}_A(t) = -\log \hat{S}_A(t)$$

Propriétés des estimateurs de S

L'étude des propriétés asymptotiques des estimateurs $\hat{S}_{KM}, \hat{S}_a, \hat{H}_{NN}, \dots$ est liée au processus ponctuel
 { martingales et la différence de martingales,
 $N_t \equiv M_t + A_t$

On arrive à :

$$E(\hat{\theta}) = \theta$$

e.s.b

$$E(\hat{S}_{KM}(t)) \xrightarrow[n \rightarrow +\infty]{} S(t) \quad (\text{estimateur sans biais asympt.})$$

$$E(\hat{S}_a(t)) \xrightarrow[n \rightarrow +\infty]{} S(t)$$

$$S_{KM}(t) \xrightarrow[n \rightarrow +\infty]{} S(t) \text{ en proba. conv. en loi.}$$

Estimation des quantiles :

Mediane : $F(M) = \frac{1}{2} \quad S(M) = \frac{1}{2}$

Si dans une étude de survie on vient de tracer $S(\hat{S}_{KM}, \hat{S}_a, \dots)$

Comment estimer la médiane M :

$$\hat{M}_n \text{ vraie; } \hat{S}_{KM}(\hat{M}_n) \approx \frac{1}{2}$$

Estimation des ~~autres~~ quantiles : α -quantiles = q_α
 estimer q_α par : $\hat{S}_{KM}(\hat{q}_{\alpha,n}) = \alpha$

on montre que $\hat{q}_{\alpha,n} \rightarrow q_\alpha$

$$(\hat{q}_{\alpha,n} \rightarrow q_\alpha)$$

$$S_{KM}(M) \rightarrow S(M) = \frac{1}{2}$$